doi:10.6041/j.issn.1000-1298.2026.07.035

基于物理信息神经网络的工厂菇房节能预测控制方法研究

王明飞[1,2]　孔祥书[3]　郭国强[2]　单飞飞[2]　郑文刚[2]　陈立平[1,2]

(1.沈阳农业大学信息与电气工程学院,沈阳 110866;2.北京市农林科学院智能装备技术研究中心,北京 100097;
3.农芯科技(北京)有限责任公司,北京 100097)

摘要:针对当前菇房模型预测控制存在数据驱动模型泛化性差、空间异质性表征不足等问题,本研究以工厂化菇房节能降耗为目标,提出一种面向异质菇房的数据机理协同建模与全域温度场协同控制方法。首先,构建面向空间异质性菇房的环境传感器优化选点模型,实现少量传感器对复杂热环境场的感知。其次,设计以全连接网络为基础架构的简化物理信息神经网络(Physics-informed neural networks, PINNs),嵌入简化 Navier-Stokes 方程与能量守恒方程作为物理约束,提升温度场预测能力。最后,构建以温度跟踪偏差与控制能耗为联合优化目标的模型预测控制(Model predictive control,MPC)框架,并在北京市房山区榆黄蘑装配式方舱菇房与北京市通州区标准化海鲜菇工厂化菇房 2 类典型环境中开展系统验证。结果表明:在仅使用 6 个传感器的稀疏监测条件下,所提方法对方舱菇房全域温度场的反演均方根误差(Root mean square error,RMSE)为 0.267℃;PINNs-MPC 在工厂化菇房实现全域精准控温,温度稳定在 14.2~15.2℃,而在方舱菇房中受强扰动与非规范农事操作影响,局部区域出现超限现象;PINNs-MPC 较传统阈值控制节能 10.7%,因控制策略偏保守,节能潜力略低于基于热平衡方程约束的 MPC,后者节能率达 13.1%。本研究有效融合物理规律与稀疏观测数据,显著提升了温度场建模精度与空间感知能力,为异质农业空间的智能节能调控提供了理论支撑与技术路径。

关键词:工厂菇房;节能;模型预测控制;深度学习;物理信息神经网络

中图分类号:S24　　**文献标识码**:A　　**文章编号**:1000-1298(2026)07-0383-13　　**OSID**:

Energy-saving Predictive Control Method for Factory Mushroom Rooms Based on Physical Information Neural Networks

WANG Mingfei[1,2]　KONG Xiangshu[3]　GUO Guoqiang[2]　SHAN Feifei[2]　ZHENG Wen'gang[2]　CHEN Liping[1,2]

(1. *School of Information and Electrical Engineering*, *Shenyang Agricultural University*, *Shenyang* 110866, *China*
2. *Intelligent Equipment Technology Research Center*, *Beijing Academy of Agriculture and Forestry Sciences*, *Beijing* 100097, *China*
3. *Nongxin Science and Technology* (*Beijing*) *Co.*, *Ltd.*, *Beijing* 100097, *China*)

Abstract: Aiming to address the issues of poor generalization of data-driven models and insufficient representation of spatial heterogeneity in current mushroom house model predictive control, a data mechanism collaborative modeling and global temperature field collaborative control method for heterogeneous mushroom houses was proposed, with the goal of energy saving and consumption reduction in industrial mushroom room production. Firstly, an environmental sensor placement optimization model was developed to capture complex thermal dynamics by using only a minimal number of sensors. Secondly, a simplified physics-informed neural networks (PINNs) architecture based on fully connected layers was designed, incorporating simplified Navier-Stokes and energy conservation equations as physical constraints to enhance temperature field prediction accuracy. Finally, an MPC framework was formulated with a joint optimization objective of temperature tracking error and energy consumption, and systematically validated in two representative production settings: a prefabricated modular Pleurotus citrinopileatus cultivation chamber in Fangshan District and a standardized Hypsizygus marmoreus factory facility in Tongzhou District of Beijing. Results showed that under sparse monitoring with only six

收稿日期:2025-10-18　修回日期:2025-11-06

基金项目:国家现代农业产业技术体系项目(CARS-20)和北京市食用菌创新团队项目(BAIC03-06)

作者简介:王明飞(1984—),男,博士生,北京市农林科学院副研究员,主要从事食用菌智能检测与相关的节能控制技术等研究,E-mail:Wangmf@nercita.org.cn

通信作者:陈立平(1973—),女,研究员,博士,主要从事精准农业技术与装备研究,E-mail:chenlp@nercita.org.cn

sensors, the proposed method achieved a root mean square error (RMSE) of 0.267℃ in reconstructing the full three-dimensional temperature field in the modular chamber. The PINNs - MPC strategy enabled precise whole-space temperature control in the standardized facility, maintaining temperatures stably within 14.2℃ to 15.2℃, whereas in the modular chamber, localized temperature violations occurred due to strong environmental disturbances and non-standardized agronomic operations. In terms of energy efficiency, PINNs - MPC reduced energy consumption by 10.7% compared with conventional threshold-based control; however, its conservative control behavior limited further savings, as a thermally constrained MPC approach based on an energy-balance equation achieved a higher reduction of 13.1%. By effectively integrating physical laws with sparse observational data, this work significantly enhanced modeling fidelity and spatial awareness of thermal fields in heterogeneous agricultural environments, offering a theoretically grounded and technically viable pathway toward intelligent, energy-efficient, and robust environmental control in modern mushroom cultivation.

Key words: factory mushroom room; energy-saving; model predictive control; deep learning; physics-informed neural networks

0 引言

食用菌工厂化生产模式具有高效率、宜机化、周年化等优势,已成为发达国家主流农业形态。在欧美国家,传统栽培已基本被工厂化栽培替代[1]。由于食用菌对所需要的温、湿、气等环境条件较为敏感,通常需采用供暖、通风和空调(Heating, ventilation, and air conditioning, HVAC)系统控制环境参数,这需要消耗大量的能源。高额能源成本逐渐成为食用菌工厂化生产企业最为关注的问题。能源成本占食用菌工厂化企业生产总成本的 10% ~ 21%[2-3],其中菇房空调系统是主要消耗设备。菇房的节能设计可通过菇房建筑改造、空调设备升级和控制策略优化等途径。其中,节能控制策略优化特别是气候温度控制方法优化是以不改变围护材料结构、电气设备安装方式等最小代价开展,往往无需大额投资,推广阻力小,具有良好的应用推广前景。现有的菇房环境控制系统仍依赖于阈值控制为主[4]。

模型预测控制(Model predictive control, MPC)在建筑领域已被诸多学者验证具有提前动作[5]、成本节约[6-8]、转移峰值负载的能力[9]及对动态干扰的鲁棒性[10]等优势。文献[11]将 MPC 系统建模划分为 3 类方法:①基于简化评估方法的灰箱模型。②基于物理规则的白箱模型。③基于纯数据驱动的黑盒模型。

白箱模型主要是通过嵌入这些物理模型的仿真程序,如 EnergyPlus[12]、DeST[13]、TRNSYS[14]和 Modelica[15]等建筑能源模拟(Building energy simulation, BES)软件。这类模型通常对建筑热模型具有较好的可解释性,但需要在不同软件间进行大量数据交互,故白箱模型构成的 MPC 运行时间较长[16]。此外,仿真工具本身存在局限性,包括建筑尺寸、材料真实传热系数等参数的不确定性、现场人员引起的突发事件、初始条件设置的不准确性等,这可能会降低 MPC 实际应用效果。

近年来,随着物联网技术、监测设备和存储技术的成熟,大量实时数据获取成本得以降低,使得基于数据驱动的 MPC 方法逐渐流行起来[17]。黑箱模型主要包括多元线性回归(Multiple linear regression, MLR)[18]、具有外源输入自回归(AutoRegressive model with eXogenous inputs, ARX)[19]、自回归移动平均线[20]、自回归综合移动平均线[21-22]、具有外生输入的自回归-移动平均值(AutoRegressive moving average model with eXogenous inputs, ARMAX)[23]等统计回归模型和 GRU、LSTM 等[24]机器学习模型。黑箱模型具有无需先验知识、工程成本低等优点,在建筑能耗控制领域得到迅速发展,然而,它们只是将建筑能耗与影响因素相关联,同时面临泛化性能不佳、可解释性差等问题[25]。对于菇房的温度数据来说,存在热平衡方程等物理规则约束,因此如何充分利用已有的知识规则作为数据驱动模型的先验知识是一个重要的改进方向[26]。

灰箱模型是一类将物理过程描述与数据驱动方法相结合的建模方法。构建灰盒模型常用方法有 2 类:一类是统一在物理框架中,使用数据驱动的方法获得一些数据;另一类使用物理知识来表征关键参数,而整个预测模型使用集成的黑盒模型构建[27]。电阻电容(Resistor - capacitor model, RC)模型是属于第 1 类常见的灰盒模型,其利用各种建筑部件(例如围护结构和室内空气)的热工机理,将各部件热传递以电学电容、电阻和电源等类比,如电压源可用于模拟温度,电容可以表示蓄热,电流可以描述热流[28]。由于 RC 模型计算效率高,可提供线性形式的全局最优,比黑箱模型更可靠,已被 MPC 广泛应用在建筑节能领域[29]。RC 模型虽具有准确性和简单性,然而开发模型需要基于建筑物描述的物理解

释、边界和初始参数值，以及研究各项参数的辨识算法。开发需要技术专长、工程知识和时间，而开发的模型不适合应用于其他建筑物，需要针对每座建筑以特定使用目的定制 MPC 模型[30]。另外，RC 模型并不能保证随着训练周期的延长而改善预测性能。因此，需借助数据驱动模型通过大量训练数据提高预测性能的优势。为解决 RC 模型应用在 MPC 中的上述问题，第 2 类灰箱模型以数据驱动模型为主，利用物理规则对关键参数进行约束。文献[31－32]将室内热量变化以热平衡方程形式引入损失函数，通过物理方程约束数据驱动，实现对室内温度的预测控制。进一步地，以物理偏微分方程为训练指导的物理信息神经网络（Physics-informed neural networks，PINNs）也在建筑环境控制中得到了应用[33－35]。然而现有面向匀质空间的模型预测控制方法大多仅关注整体能量平衡，未能充分考虑由空气流动、菌包布局及送风方式等因素引起的显著空间温度梯度。在实际异质性强的菇房环境中，局部过热、过冷或通风死角的存在，容易导致蘑菇生长不均，严重影响其整齐度与商品率。传统的基于平均温度的控制策略，由于难以感知不同高度与区域的环境差异，因而无法实现对菇房内部温度的精准分区调控。

综上所述，针对当前菇房 MPC 存在数据驱动模型泛化性差、空间异质性表征不足等问题，本研究将以工厂化菇房节能降耗为目标，提出面向异质菇房的数据机理协同建模与全域温度场协同控制方法，旨在为异质空间环境的精细化调控提供可行技术路径。一方面，将研究多指标融合的传感器优化布设方法，综合主成分贡献率、信息熵、重建误差，在仅部署少量测点的条件下实现对复杂热环境的有效感知；继而将构建嵌入简化 Navier－Stokes 方程与能量守恒律的物理信息神经网络，利用稀疏观测数据实现三维温度场的高精度动态反演；另一方面，将该模型嵌入模型预测控制框架，引入设备启停最小持续时间等工程约束，形成面向局部微环境的协同节能调控策略，实现从点控制向场控制的跨越。最后将依托北京市通州区标准化海鲜菇工厂化菇房与北京市房山区榆黄蘑装配式方舱菇房两类典型生产环境，对多场景下建模与控制方法开展系统验证。

1　方法与材料

1.1　面向空间异质性菇房的环境传感器优化选点模型构建

大空间菇房内温度易产生不一致，且受制于传感器成本，需选择部分位置进行持续监测。本文从平均温度均方根误差、传感器贡献率、信息捕获率及传感器数量为评价指标，构建选择环境传感器的目标函数。

1.1.1　平均温度均方根误差

为评估所选传感器与所有传感器温度偏差，设计所选传感器平均温度与所有传感器平均温度的均方根误差为评价指标。

$$e_T = \mathrm{RMSE}\left(\sum_{i \in S} T_i \Big/ s,\ \sum_{j \in M} T_j \Big/ m \right) \tag{1}$$

式中　s、m——被选传感器、所有传感器的数量

S、M——被选传感器、所有传感器的集合

T_i、T_j——第 i、j 个传感器中所测温度数据，℃

e_T——平均温度均方根误差，℃

RMSE(·)——均方根误差计算函数

1.1.2　方差贡献率

为评估所选传感器对菇房温度波动模式的贡献程度，引入 PCA 方法计算各传感器对环境数据的方差贡献率（Variance contribution rate，VCR）。PCA 方法是一种数学降维方法，利用正交变换把一系列可能线性相关的变量转换为一组线性不相关的新变量，也称为主成分，从而利用新变量在更小的维度下展示数据的特征[36]。本文利用 PCA 方法捕捉温度场全局变化，对原始传感器矩阵降维，并找出影响温度场的关键传感器。其主要计算过程如下：

（1）前 N 个主成分中传感器 i 贡献率 $g_{N,i}$ 计算式为

$$g_{N,i} = l_{N,i}^2 \Big/ \sum_{i=1}^{m} l_{N,i}^2 \tag{2}$$

式中　$l_{N,i}$——PCA 方法中载荷矩阵中的元素，表示传感器 i 与主成分 N 的相关系数

（2）被选传感器贡献占比 η_{VCR} 计算式为

$$\eta_{\mathrm{VCR}}(S) = \sum_{i \in S} G_i \Big/ \sum_{j \in M} G_j \tag{3}$$

式中　G_i、G_j——传感器 i、j 在主成分中的贡献率

1.1.3　信息捕获率

为衡量现有传感器网络配置对系统状态的整体感知能力，基于信息熵设计信息捕获率，以期最大化保留系统原始信息。与 PCA 仅捕捉环境数据间的线性相关性不同，信息熵更关注捕捉传感器间的非线性冗余信息。

信息捕获率（Information capture rate，ICR）以数据的信息熵为基础，计算已选传感器数据在系统总熵中的占比。计算过程如下：

（1）全部传感器温度数据之间的不确定性总和，即总熵 E_{total} 计算式为

$$E_{\mathrm{total}} = \sum_{i=1}^{m} R(T_i) \mathrm{lb} R(T_i) \tag{4}$$

式中 $R(T_i)$——在全部温度数据之间取值 T_i 的概率

(2)未选传感器集合 $\overline{S}$ 在所有传感器条件下的不确定性,即条件熵 E_{joint} 计算式为

$$E_{\text{joint}}(\overline{S}) = H(T_{\overline{S}} \mid T_M) \tag{5}$$

式中 $H(T_{\overline{S}} \mid T_M)$——未选传感器温度 $T_{\overline{S}}$,在所有传感器温度 T_M 下的条件熵

(3)被选传感器信息捕获率 η_{ICR} 计算式为

$$\eta_{\text{ICR}}(S) = 1 - E_{\text{joint}}(\overline{S}) / E_{\text{total}} \tag{6}$$

根据期望所选传感器子集的平均温度均方根误差最小、传感器贡献率最大、信息捕获率最大及传感器数量最少原则,设计目标函数为

$$J_{\text{sensor}} = \min(e_T + 1 - \eta_{\text{VCR}}(S) + 1 - \eta_{\text{ICR}}(S) + \delta s) \tag{7}$$

式中 δ——传感器数量对应的权重系数

1.2 基于偏微分方程约束的神经网络建模方法

PINNs 作为一种新兴的机器学习框架,为解决偏微分方程计算问题提供了全新的思路和途径。其核心思想是将神经网络与物理定律相结合,通过将偏微分方程作为网络训练过程中的约束条件,使得神经网络能够在学习数据的同时,也满足物理定律的约束。其主要由全连接网络(Fully connected network,FCN)和物理偏微分方程组成。

1.2.1 全连接网络模型结构设计

FCN 是 PINNs 中用于逼近未知物理场函数的神经网络结构,一般由输入层、1 个或多个隐藏层、输出层组成。FCN 的结构特点使其高效地利用 TensorFlow、PyTorch 等现代深度学习框架的自动微分功能来计算神经网络输出对输入特征中空间、时间的偏导数,这些导数正是构成偏微分方程所必需的。物理方程通过损失函数约束 FCN 的输出及其导数。

本研究 FCN 中由 1 个输入层、1 个输出层与 8 个隐藏层组成,用于特征的深度提取与转换。每个隐藏层含 64 个神经元,以 tanh 为激活函数,以增强输入与输出之间的非线性映射能力。输出层不使用激活函数旨在网络能够输出任意实数范围的值。

1.2.2 物理信息网络模型损失函数设计

PINNs 用于求解受物理定律约束的科学计算问题,关键在于表述出反映物理现象的物理方程,其将描述物理系统的控制方程、边界条件、初始条件以及可能存在的观测数据,作为软约束直接嵌入到神经网络的损失函数参与训练过程。

(1)动量方程

将 Navier-Stokes 方程的动量方程在笛卡尔坐标系下以标量形式展开

$$\begin{cases} \dfrac{\partial(\rho u)}{\partial k} + \dfrac{\partial(\rho uu)}{\partial x} + \dfrac{\partial(\rho uv)}{\partial y} + \dfrac{\partial(\rho uw)}{\partial z} = \\ \quad \mu\left(\dfrac{\partial^2 u}{\partial x^2} + \dfrac{\partial^2 u}{\partial y^2} + \dfrac{\partial^2 u}{\partial z^2}\right) - \dfrac{\partial P}{\partial x} + F_u \\ \dfrac{\partial(\rho v)}{\partial k} + \dfrac{\partial(\rho vu)}{\partial x} + \dfrac{\partial(\rho vv)}{\partial y} + \dfrac{\partial(\rho vw)}{\partial z} = \\ \quad \mu\left(\dfrac{\partial^2 v}{\partial x^2} + \dfrac{\partial^2 v}{\partial y^2} + \dfrac{\partial^2 v}{\partial z^2}\right) - \dfrac{\partial P}{\partial y} + F_v \\ \dfrac{\partial(\rho w)}{\partial k} + \dfrac{\partial(\rho wu)}{\partial x} + \dfrac{\partial(\rho wv)}{\partial y} + \dfrac{\partial(\rho ww)}{\partial z} = \\ \quad \mu\left(\dfrac{\partial^2 w}{\partial x^2} + \dfrac{\partial^2 w}{\partial y^2} + \dfrac{\partial^2 w}{\partial z^2}\right) - \dfrac{\partial P}{\partial z} + F_w \end{cases} \tag{8}$$

式中 ρ——空气密度,kg/m^3

P——压力,Pa

u、v、w——速度矢量在 x、y、z 方向的速度分量,m/s

μ——有效动力黏度系数,取 1.8×10^{-5} Pa·s

F_u、F_v、F_w——外部作用的动量源项,N/m^3

k——时间步长

在公式(8)中,空调系统运行所产生的送风气流通过动量源项的形式被引入 Navier-Stokes 方程组,以实现对强制对流效应的数学表征。然而,过大的送风量易导致食用菌表面水分蒸发加剧,相对湿度降低,进而抑制菌丝生长并影响出菇品质。为缓解此问题,实际菇房设计通常在空调出风口与栽培区之间设置独立缓冲区域或采用风管送风方式,用以衰减气流能量,降低主生长区内的空气流速。在此优化布局下,动量源项对栽培区域流场的影响显著减弱,可予以忽略。

实测数据表明,食用菌生长区内的气流速度多分布于 0.1~0.5 m/s。基于该流速范围估算所得的雷诺数远高于层流-湍流转换的临界值,表明流动处于惯性力主导、黏性效应可忽略的湍流状态,其动力学行为主要由对流机制控制。

基于上述流动特性,在构建物理信息神经网络的过程中,对动量方程物理残差损失的计算进行了合理简化:忽略黏性扩散项,仅保留时间导数项与非线性对流项。该简化处理不仅降低了控制方程的数值复杂度,提高了训练效率,也有助于缓解因速度梯度估计所引发的数值不稳定性。

(2)温度方程

Navier-Stokes 方程中温度方程在笛卡尔坐标系下以标量形式展开

$$\frac{\partial(\rho T)}{\partial k} + \frac{\partial(\rho uT)}{\partial x} + \frac{\partial(\rho vT)}{\partial y} + \frac{\partial(\rho wT)}{\partial z} = \frac{h}{c_p}\left(\frac{\partial^2 T}{\partial x^2} + \frac{\partial^2 T}{\partial y^2} + \frac{\partial^2 T}{\partial z^2}\right) + F_T \tag{9}$$

式中　h——流体传热系数，W/(m·K)

c_p——空气定压比热容，kJ/(kg·K)

F_T——流体内热源项，W/m^3

T——流体温度，K

菇房中的热源 S_T可分为 4 项，分别为新风带来的换热流量，空调对空气单位体积的供冷流量，单位体积下室外经围护结构、地面传递到室内的热流量和单位体积菌菇呼吸产生的热流量。

食用菌种植区域内的流体流动主要受空气对流主导，其空气流速范围约为 0.1 ~ 0.5 m/s。经计算，该条件下的佩克莱特数远大于 1，表明在能量输运过程中，对流传热效应显著强于热传导效应。因此，可忽略热传导项的贡献，将传热过程简化为以对流为主导的模型。综上所述，由公式(8)、(9)可得，温度和速度在 x、y、z 上分量的物理损失项 l_T、l_x、l_y、l_z 为

$$\begin{cases} l_T = \left| \rho \left(\dfrac{\partial T}{\partial k} + \dfrac{\partial (uT)}{\partial x} + \dfrac{\partial (vT)}{\partial y} + \dfrac{\partial (wT)}{\partial z} \right) - F_T \right| \\ l_x = \left| \rho \left(\dfrac{\partial u}{\partial k} + \dfrac{\partial (uu)}{\partial x} + \dfrac{\partial (uv)}{\partial y} + \dfrac{\partial (uw)}{\partial z} \right) + \dfrac{\partial P}{\partial x} \right| \\ l_y = \left| \rho \left(\dfrac{\partial v}{\partial k} + \dfrac{\partial (vu)}{\partial x} + \dfrac{\partial (vv)}{\partial y} + \dfrac{\partial (vw)}{\partial z} \right) + \dfrac{\partial P}{\partial y} \right| \\ l_z = \left| \rho \left(\dfrac{\partial w}{\partial k} + \dfrac{\partial (wu)}{\partial x} + \dfrac{\partial (wv)}{\partial y} + \dfrac{\partial (ww)}{\partial z} \right) + \dfrac{\partial P}{\partial z} \right| \end{cases} \tag{10}$$

PINNs 可通过传感器的数据损失项间接学习到边界与初始行为，同时研究聚焦于核心种植区域温度变化，远离墙体等物理边界，此时可简化对边界与初始损失的处理，故总损失函数为

$$l = l_T + l_x + l_y + l_z + l_{\text{data}} \tag{11}$$

式中　l_{data}——数据损失函数，采用默认 MAE 函数

1.2.3　物理信息神经网络模型设计

在菇房热动态时序建模方面，由于菇房建筑结构具有较大的热惯性，且空气与围护结构之间存在复杂的非稳态传热过程，室内温度响应相对于外部环境扰动或控制输入呈现出显著的时滞性和动态滞后特性。为准确刻画这一具有记忆效应的热动态行为，提升模型对温度演变趋势的预测能力，本文以 10 min 为数据采集及控制周期，并引入温度传感器所采集的历史时序数据和室外历史环境温度作为输入特征集。

在菇房热动态空间建模方面，菇房内部温度在三维空间中呈现显著的非均匀性，受送风方式、热源分布、建筑结构及出菇区域布局等因素影响，不同位置的温升或温降趋势存在差异。为实现对全场温度分布的连续建模与高分辨率预测，PINNs 需以空间坐标作为输入，输出对应位置的温度值，故输入特征集进一步包括传感器的空间坐标。另外，还需将历史及现时段内空调控制时长纳入模型输入特征集。

在热量传输过程中，压力与流体速度是影响对流传热行为的关键物理量。然而，在实际工程测量中，难以精确获取菇房内部各空间位置在 3 个正交方向上的速度分量及压力。为此，本研究将速度场 u、v、w 与压力 P 作为变量纳入模型预测范畴，将其与目标温度场 T_{in}同时设为模型输出变量。PINNs 网络结构的输入输出集如表 1 所示。

表 1　物理信息神经网络模型输入输出集

Tab. 1　Input and output set of PINNs model

特征	变量	符号	备注
模型输入集合	时段	k	
	室外温度	$T_{\text{out}}(k)$	在 k 时段内平均温度
	室内温度	$T_{\text{in_1}}(k-1)$, $T_{\text{in_2}}(k-1)$, ⋯, $T_{\text{in_}s}(k-1)$	所选传感器在 $k-1$ 时段内平均温度
		$T_{\text{in_1}}(k-2)$, $T_{\text{in_2}}(k-2)$, ⋯, $T_{\text{in_}s}(k-2)$	所选传感器在 $k-2$ 时段内平均温度
		$T_{\text{in_1}}(k-3)$, $T_{\text{in_2}}(k-3)$, ⋯, $T_{\text{in_}s}(k-3)$	所选传感器在 $k-3$ 时段内平均温度
	设备	$d(k)$	在 k 时段内设备运行总时长
		$d(k-1)$	在 $k-1$ 时段内设备运行总时长
		$d(k-2)$	在 $k-2$ 时段内设备运行总时长
		$d(k-3)$	在 $k-3$ 时段内设备运行总时长
	位置	$x_1, x_2, \cdots, x_s$	所选传感器位置的 x 轴坐标
		$y_1, y_2, \cdots, y_s$	所选传感器位置的 y 轴坐标
		$z_1, z_2, \cdots, z_s$	所选传感器位置的 z 轴坐标
模型输出集合	速度场	$u_1(k), u_2(k), \cdots, u_s(k)$	所选传感器的速度分量 $u(k)$
		$v_1(k), v_2(k), \cdots, v_s(k)$	所选传感器的速度分量 $v(k)$
		$w_1(k), w_2(k), \cdots, w_s(k)$	所选传感器的速度分量 $w(k)$
	压力场	$P_1(k), P_2(k), \cdots, P_s(k)$	所选传感器的压力场 $P(k)$
	温度场	$T_{\text{in_1}}(k), T_{\text{in_2}}(k), \cdots, T_{\text{in_}s}(k)$	所选传感器在 k 时段内平均温度

通过构建包含数据驱动损失项与基于控制方程的物理残差损失项的复合损失函数,利用反向传播算法对速度与压力进行反向校正,以实现考虑传热过程的物理一致性建模。最终建立面向菇房环境的三维温度场预测模型,如图 1 所示。

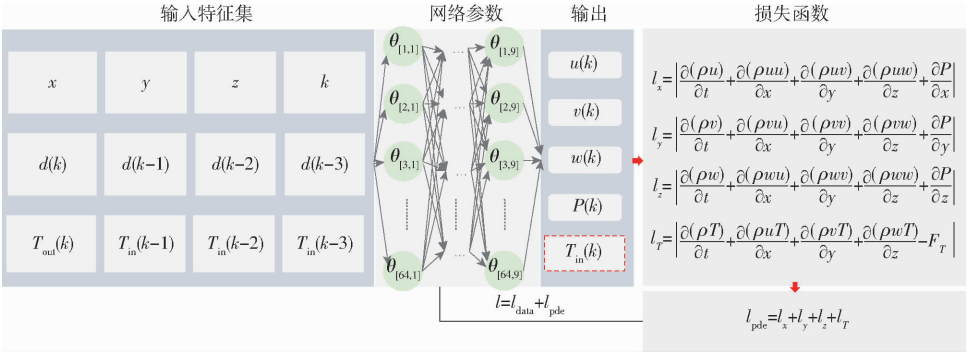


图 1 PINNs 模型结构

Fig. 1 PINNs model structure

1.3 基于物理信息神经网络的节能目标函数优化求解

MPC 通过求解目标函数得到控制时域内的最优控制量。本文在满足食用菌最佳农艺条件下生长温度范围的同时,以期空调开启时长最短,基于系统输出与参考轨迹的偏离程度和空调设备的控制量建立目标函数;综合考虑求解速度以及全局性控制,控制时域选择为 5;同时考虑到频繁的空调启停会损害其使用寿命,因此以空调启停最短 3 min 为硬约束。目标函数计算式为

$$J_{\mathrm{MPC}}(k)=\sum_{k=1}^{5}\left(\sigma_1 A(k)+\sigma_2 d^2(k)\right) \tag{12}$$

其中

$$A(k)=\begin{cases}(T_{\mathrm{pre}}(k)-T_{\mathrm{in-min}}(k))^2 & (T_{\mathrm{pre}}(k)<T_{\mathrm{in-min}}(k))\\ (T_{\mathrm{pre}}(k)-T_{\mathrm{in-max}}(k))^2 & (T_{\mathrm{pre}}(k)>T_{\mathrm{in-max}}(k))\\ 0 & (\text{其他})\end{cases} \tag{13}$$

式中 $A(k)$——精度项

σ_1、σ_2——精度项与能耗项的系数

$T_{\mathrm{in-min}}$——室内设定温度下限,℃

$T_{\mathrm{in-max}}$——室内设定温度上限,℃

T_{pre}——模型预测温度,℃

为求解式(12),本文选择自适应粒子群优化(Adaptive particle swarm optimization, APSO)算法,其是对传统 PSO 方法的显著改进,旨在克服标准 PSO 在复杂优化问题中易陷入局部最优、收敛速度慢或后期精度不足等问题。APSO 的核心思想是通过动态调整关键算法参数,使搜索过程在全局探索与局部开发之间实现智能平衡。在迭代初期,算法保持较大的惯性权重,以增强粒子的全局搜索能力,避免过早收敛;随着迭代进行,惯性权重自适应递减至 0.4,提升局部精细搜索能力。同时,个体认知学习因子通常从 2.5 逐渐减小至 0.5,减少个体经验对粒子的过度影响;而社会认知系数从 0.5 逐渐增加至 2.5,增强群体协作与信息共享。此外,APSO 常引入停滞检测代数,当最优解长时间未更新时,触发变异或混沌扰动机制,帮助粒子跳出局部极值。种群数量通常设为 30 ~ 50,以保证多样性与计算效率的平衡。最大迭代次数根据问题复杂度以及问题求解的实时性设定。APSO 算法各项参数设置如表 2 所示。

表 2 APSO 算法参数设置

Tab. 2 Parameter settings of APSO algorithm

参数	取值
种群数量	30
惯性权重范围	0.4 ~ 0.9
自身学习因子	0.5 ~ 2.5
社会学习因子	2.5 ~ 0.5
停滞检测代数	2
迭代次数	5

1.4 试验材料与方法

北京市通州区试验菇房结构、数据参考文献[17]。北京市房山区试验在鸿泽嘉园种植合作社开展,食用菌种植种类为榆黄蘑、平菇等侧耳类。独立菇房长 12 m,宽 5 m,高 3.2 m,地基铺设隔热层后浇筑混凝土,四周及屋顶采用铝面聚氨酯夹芯板作为菇房围护结构。为降低太阳辐射影响,在其顶部建遮阳棚。

榆黄蘑出菇阶段需要温度控制在 15 ~ 25℃。菇房制冷源亦为定频空调系统,如图 2 所示。新风经过空气处理机组加热或制冷后,经风管送至菇房,菇房上部设有回风口。

菇房内的传感器布局如图 3 所示。图中红色代表的温湿度传感器在空间中部沿东西方向均匀设置

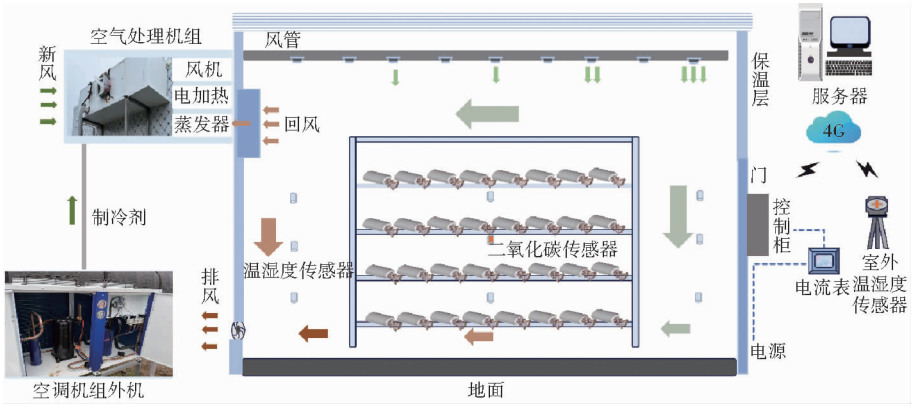


图 2　试验菇房原理图

Fig. 2　Schematic of test mushroom room

了 2 个测量点，并在接近墙壁的位置沿同一方向额外布置了 3 个测点，以捕捉边界处的环境变化。此外，在栽培层架的垂直方向上等间距地设置了 2 层传感器，确保对不同高度层次的温湿度进行监测。通过这种多层次、多位置的布设方式，共安装了 16 个温湿度传感器，旨在全面、准确地反映菇房内部环境条件的空间分布特性。2 个柔性热通量板贴附在不同的榆黄蘑菌包表面，以期获取菌包热流密度。试验时间为 2025 年 5 月 15 日至 8 月 14 日。

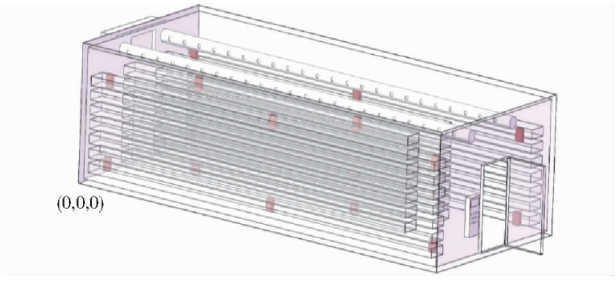


图 3　菇房内温湿度传感器布局

Fig. 3　Temperature sensor layout in mushroom room

菇房内 16 个温湿度传感器的三维坐标如表 3 所示，坐标原点见图 3。

表 3　传感器三维坐标

Tab. 3　Three-dimensional coordinates of sensor

传感器编号	坐标(x, y, z)/m	传感器编号	坐标(x, y, z)/m
1	(0.45, 0.6, 2.35)	9	(7.68, 2.12, 2.35)
2	(0.45, 0.6, 0.35)	10	(7.68, 2.12, 0.35)
3	(5.45, 0.6, 2.35)	11	(0.45, 4.6, 2.35)
4	(5.45, 0.6, 0.35)	12	(0.45, 4.6, 0.35)
5	(11.45, 0.6, 2.35)	13	(5.45, 4.6, 2.35)
6	(11.45, 0.6, 0.35)	14	(5.45, 4.6, 0.35)
7	(1.92, 2.12, 2.35)	15	(11.45, 4.6, 2.35)
8	(1.92, 2.12, 0.35)	16	(11.45, 4.6, 0.35)

菇房实测数据示例如图 4 所示，其中图 4a 为菇房内 16 个温湿度传感器（编号为 1～16）温度数据；图 4b 为其余环境参数实测结果，包含室外温度、空调开启时长以及菌棒热流密度。

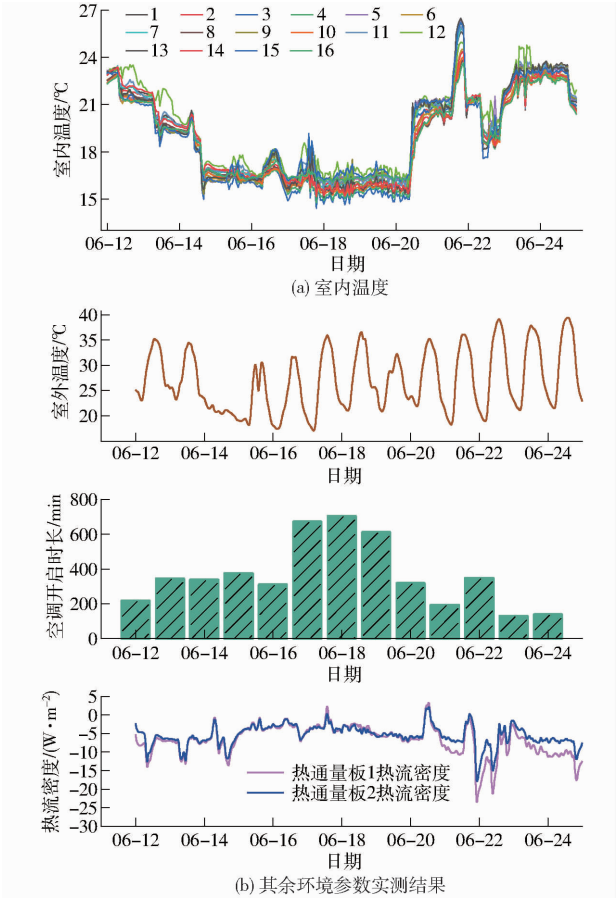


图 4　菇房采集数据

Fig. 4　Collecting data from mushroom farm

2　结果与分析

2.1　面向温度场重构的传感器最优布设与数据集筛选

为验证被选传感器数据对预测模型预测精度的影响，以 6 月 12—22 日之间的数据作为训练集，并对 6 月 24 日数据进行测试，不同训练集下 PINNs 对所有传感器数据的预测效果如图 5 所示。

以被选传感器为训练集对部署所有 16 个传感

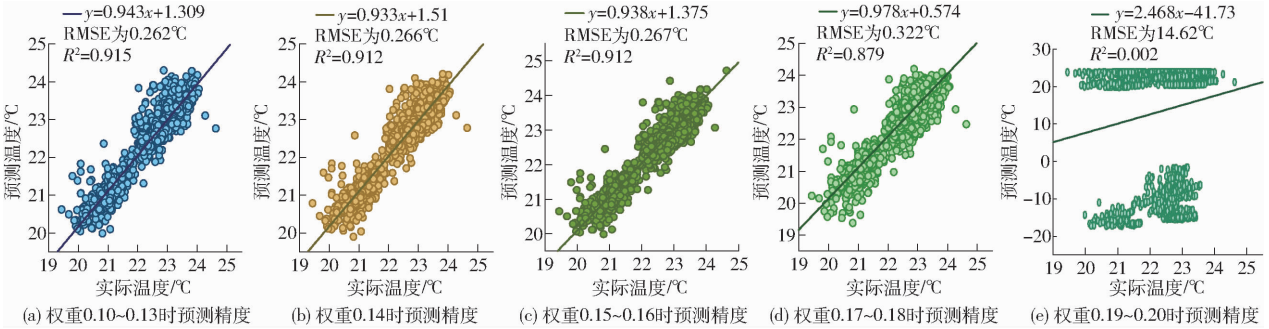


图 5 不同传感器权重下的预测精度对比

Fig. 5 Comparison of prediction accuracy under different sensor weights

器进行预测的精度称为温度场反演精度。由图 5 可知,随着多维选点方法中传感器权重 δ 的增大,对温度场反演精度逐渐降低。当 δ 为 0.10 ~ 0.13 时反演精度 R^2 为 0.915、RMSE 为 0.262℃;当 δ 为 0.15 ~ 0.16 时反演精度 R^2 为 0.912、RMSE 为 0.267℃;当 δ 继续增大至 0.17 时反演精度出现明显下降,R^2 为 0.879、RMSE 为 0.322℃;最后当 δ 增大至 0.19 时,此时模型已经完全失去了反演能力。

试验结果表明,当 δ 超过 0.15 时,进一步增大其取值并不能显著提升模型的反演精度,表明在 δ 处于 0.15 ~ 0.16 区间时,所选传感器数据已具备足够的信息以有效表征菇房室内温度场的分布特征。然而,随着 δ 值的增加,所需传感器数量相应增多,从而导致模型训练时间延长和传感器部署成本上升。因此,为在保证反演精度的前提下尽可能减少传感器使用数量,确定 δ 取值于 0.15 ~ 0.16 区间时所选取的 6 组传感器数据(传感器 1、6、8、9、11 和 14)为最优训练数据集。

2.2 温度场预测模型反演精度验证与对比分析

为验证本文提出的基于 PINNs 预测模型反演精度,选取 2025 年 6 月 24 日的实际数据作为案例进行分析,并与其他先进的神经网络模型进行了对比试验。鉴于门控循环单元(Gated recurrent unit, GRU)及其变体在网络结构上对时间序列数据表现出优异的预测性能,本文选择 GRU 及其改进版作为主要比较对象。具体而言,选取 GRU、热平衡约束 GRU(Thermal equilibrium constrained GRU, TEC - GRU)、FCN、GRU - PINN 4 种算法进行系统性能对比。其中,FCN 为传统 PINNs 中常用的前馈网络组件,其将传统 PINNs 中的 FCN 主干网络替换为 GRU,以更好地捕捉时间动态特性,其内部偏微分方程的构建方式及损失函数的设计原则均与标准 PINNs 方法保持一致。而 TEC - GRU 模型,则仅将热平衡方程代入模型训练的损失函数中,建模方法参考文献[31]。

为兼顾模型性能与计算效率,本文对所提出的 GRU - PINNs 架构进行了不同复杂度的配置设计。其中,GRU - PINNs - 2 采用 8 层堆叠的 GRU 结构,以充分挖掘时间序列中的深层动态特征。对于 TEC - GRU 模型,将室内温度动态变化通过菇房热平衡关系转换为热量变化形式,并将其作为物理约束项引入损失函数的计算中。所有对比模型均在统一的训练配置下进行试验,以确保结果的公平性与可比性:学习率统一设为 0.001;优化器采用 Adam;最大训练迭代次数为 3 000 代;模型均采用 8 层网络结构;各层神经元数量统一设为 64;激活函数方面,GRU 与 TEC - GRU 采用 ReLU,其余模型均采用 tanh 函数。温度场反演性能如表 4 所示。

表 4 多模型温度场反演性能对比

Tab. 4 Comparison of multi-model temperature field inversion performance

模型	RMSE/℃	R^2	训练时长/min
GRU	1.144	0.465	13
FCN	0.554	0.908	3
TEC - GRU	0.611	0.586	15
PINNs	0.267	0.912	54
GRU - PINNs	0.566	0.713	768

由表 4 可知,传统 GRU 模型在温度场反演任务中表现欠佳,其反演精度为:RMSE 为 1.144℃,R^2 为 0.465;其物理信息融合变体 TEC - GRU 虽通过引入局部热平衡方程对物理规律进行初步建模,反演精度提升至:RMSE 为 0.611℃,R^2 为 0.586,但仍难以满足高精度建模需求。分析其原因在于:GRU 类模型虽擅长捕捉温度时间序列的动态演化特性,但在空间维度上缺乏显式的空间关联建模机制,仅依赖时序隐状态传递进行间接空间推断,难以有效表征复杂流-热耦合系统中的非线性空间分布特征。此外,TEC - GRU 中内嵌的热平衡方程仅作用于单个传感器节点,局限于局部能量守恒约束,未能刻画传感器之间的温度传播路径与因果关联,导致空间泛化能力受限。因此,GRU 及其改进模型在全局温度场重构任务中存在本质局限,难以满足 MPC 框架

对高精度、高可靠性状态估计的严格要求，故不适用于本研究的控制体系。

相较而言，GRU－PINNs 网络通过深度融合数据驱动与物理先验，在温度场反演性能上实现进一步提升。其中，GRU－PINNs 模型 RMSE 为 0.566℃，R^2 为 0.713，训练耗时为 768 min。相比之下，FCN 温度场反演的 RMSE 为 0.554℃、R^2 为 0.908，训练耗时仅为 3 min；而 PINNs 则达到了更高的预测精度，其反演误差降低至 RMSE 为 0.267℃、R^2 为 0.912，但训练耗时为 54 min。结果表明，FCN 在温度场重建性能上仅次于 PINNs，且在训练效率方面具有显著优势，但其 0.554℃的反演误差仍相对显著，在 MPC 框架下可能导致状态估计偏差，进而使控制策略偏离最优运行轨迹，影响节能效果。尤其对于以天为周期进行模型更新的 MPC 系统，模型精度的微小提升可带来显著的长期能耗优化空间。相比之下，PINNs 凭借其深度融合物理守恒律的能力，能够更准确地表征流热耦合场的复杂动态，有效挖掘节能潜力。在 MPC 框架中，温度预测模型的精度直接决定了控制量优化求解的准确性，进而显著影响整个闭环控制系统的温控性能与能效表现。因此，构建高精度的温度场预测模型是保障 MPC 系统稳定、高效运行的关键前提。

进一步地，根据文献[37]的研究，当建筑室内预测温度与实测温度的偏差达到 0.14℃时，可能导致 MPC 控制策略能耗上的差异为 5% ~5.8%。若将该结论外推至本研究的工厂化菇房环境，假设 MPC 对温度预测误差的敏感性相似，则在空调机组额定功率 8.7 kW、日均负荷率 70% 的工况下，日均电能消耗约为 146.2 kW·h。由此估算，该预测误差可能导致每日额外能耗增加 7.3 ~8.5 kW·h，这对系统运行的温控精度与能源效率均产生显著不利影响。基于上述分析，本文将提升温度预测模型精度作为核心研究目标，力求在保证计算效率的同时实现对菇房温度场的高保真重构。鉴于 PINNs 在融合数据与物理先验方面的独特优势，本研究采用 PINNs 作为核心建模工具。尽管其训练耗时较长，但可通过离线训练、在线部署的方式实现模型更新与实时控制的解耦，既保障预测精度，又满足系统实时性需求。

2.3　典型日工况下 MPC 节能调控性能的仿真验证

在模型预测控制系统的运行过程中，传感器数据作为关键的反馈信息，需实时传输至 MPC 控制器。本文将此类传感器数据定义为“控制基点”，菇房空调的启停逻辑将依据控制基点所采集的温度变化数据进行动态调节。为构建基于物理信息神经网络的 MPC 模型（PINNs－MPC），选取传感器 1、6、8、9、11 和 14 作为训练所用的传感器，其采集的数据既作为模型训练的输入，亦作为实际控制中的控制基点。其余传感器布设位置则作为观测点，其温度预测值通过模型在各观测点初始状态条件下，基于 3 组历史温度数据，结合控制基点生成的控制量，经由 MPC 框架下的滚动优化与迭代预测过程获得。

为验证本文所提出模型的节能调控效果，选取榆黄蘑快速生长期的实测数据进行仿真测试。快速生长期界定为 2025 年 6 月 12—17 日，菌包于 6 月 11 日入库。入库初期（6 月 11—13 日），为促进菌丝体的充分生长，菇房维持在相对较高温度环境。自 6 月 13 日起进入出菇阶段，为提升出菇品质并优化子实体口感，于当日 07:30 将菇房温度由 21 ~23℃调控至 19 ~21℃，该温度区间持续至 6 月 14 日 18:00；随后进一步将目标温度下调至 16 ~18℃，并维持至采收结束。

以 6 月 13 日为例，00:00 至 07:30 期间，菇房温度设定阈值为 21 ~23℃；07:30 至 24:00 则调整为 19 ~21℃。在此动态温控策略下，模型的节能仿真控制效果如图 6 所示。

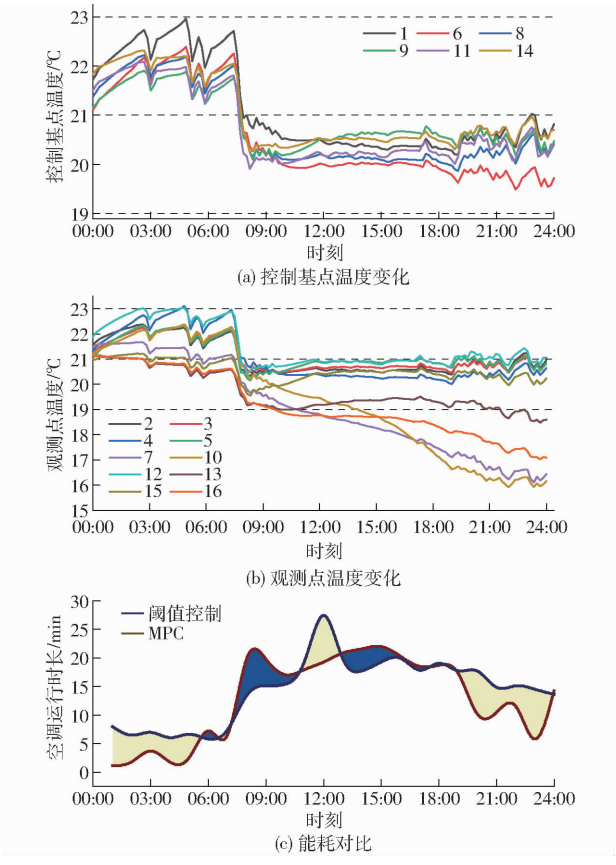


图 6　节能仿真控制效果

Fig. 6　Energy-saving simulation control effect

在阈值控制策略下，控制基点的平均温度为 20.302℃；而采用 MPC 方法优化后，如图 6a 所示，

控制基点平均温度提升至 20.840℃，二者均处于设定温控范围之内，表明 2 种控制策略均可实现温度调控功能。然而，在部分观测点位（7、10、16），如图 6b 所示，温度预测中出现了显著偏差。观测点 7 位于空调回风口附近，在子实体生长阶段，菇房以回风换气为主，局部气流扰动强烈；而观测点 10 与 16 邻近菇房入口区域，受人员频繁进出等操作活动影响，热环境波动显著。上述区域存在较强的局部动态扰动，导致基于 PINNs 构建的温度场模型所依赖的简化假设不再适用。因此，模型难以准确表征控制量与部分观测点响应间的复杂非线性耦合关系，最终表现为预测值偏离实测数据。相比之下，环境相对稳定的区域，其热力边界条件变化较小，物理场演化更符合模型假设，因而预测精度较高，体现了 PINNs 在满足建模前提下的有效性与可靠性。

如图 6c 所示，为应对室内温度设定阈值的下调，MPC 策略因预测时域提前在 07:00 至 07:30 间调节控制量，主动增加制冷输出，实现冷负荷的前瞻性调节；而传统阈值控制方法则表现出明显滞后性，直至 12:00，因室外气温升高导致冷负荷需求上升时才大幅延长空调运行时长。然而，由于该方法未考虑建筑围护结构热惯性引起的温度响应时滞，短期内制冷供给未能匹配实际热负荷，造成冷量供应不足，并在 13:00 出现补偿性降温减弱的现象，反映出其“被动反应式”控制机制的局限性。统计结果显示，采用 MPC 策略时空调累计制冷时长为 309 min，较阈值控制下的 346 min 减少 37 min，节能率达 10.7%。综合榆黄蘑夏季出菇周期的多组试验数据，本文所提出的 MPC 节能优化策略在各类工况下均展现出良好的适应性与节能潜力，整体节能率稳定维持在 9.8% ~14.6%。

综上所述，尽管在出入口、排风口、回风口等强扰动区域，速度场与温度场剧烈变化导致物理模型简化假设失效，进而影响局部预测精度，但 MPC 仍能基于控制基点的可靠预测实现全局能耗优化。

3 讨论

3.1 不同菇房中控制基点与观测点温控偏差成因分析

在海鲜菇菇房环境中（数据及菇房环境参考文献[31]），将基于物理信息神经网络的 MPC 应用在其温度调控中。其中筛选出的控制基点为传感器 1、5、6 与 10。8 月 21 日节能仿真控温范围如图 7 所示。

试验结果表明，在海鲜菇菇房环境中，无论控制基点（图 7a）还是观测点（图 7b），其温度均能被有效维持在预设范围（14.2 ~ 15.2℃）内，实现了良好的全局温控一致性。相比之下，在榆黄蘑菇房中，尽管控制基点温度满足设定要求，靠近回风口及出入门区域部分观测点频繁出现超限现象，表现出明显的局部热环境失控特征。上述差异的根本原因可归结为两类菇房在气体调控需求、环境扰动特性以及农事管理规范性方面的显著不同。

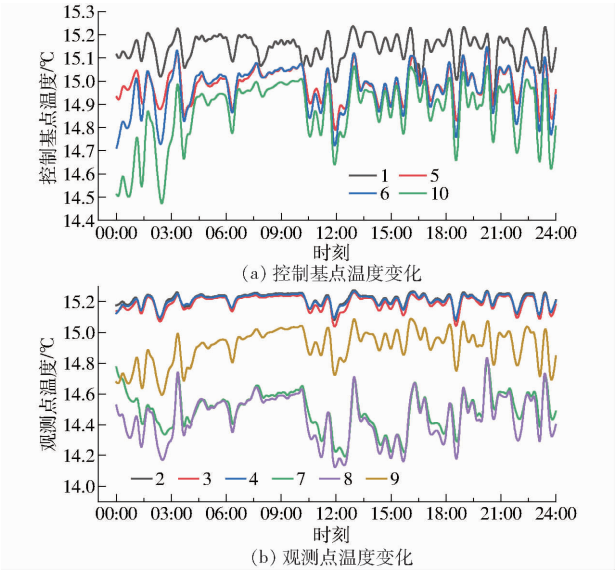


图 7 海鲜菇菇房节能仿真控制效果

Fig. 7 Energy-saving simulation control effect of seafood mushroom cultivation houses

首先，从生理特性与通风策略分析，海鲜菇具有较强的耐高浓度 CO_2 能力，日常管理中换气频率低、通风量小，系统主要扰动源为空调启停引起的周期性热波动以及菌丝代谢产热，整体环境动态呈现较强的时间规律性与可预测性，有利于 PINNs - MPC 模型对温度演化趋势进行准确建模与前瞻性调控。而榆黄蘑对 CO_2 浓度高度敏感，必须通过频繁开启新风系统以维持适宜气体环境。此过程导致大量外界高温空气瞬时涌入，引发强烈非稳态扰动。尤其在门体开启期间，室内外空气形成剧烈掺混，在门口附近产生冷热交界面；同时，回风口区域因负压效应易形成低温聚集区或气流滞留区，进一步加剧了温度场的空间异质性与时间波动性。此类复杂、突发性强的多物理场耦合扰动，已超出当前 PINNs - MPC 模型在线预测与响应的能力边界，导致局部温控失效。

其次，从农事管理实践角度分析，当前海鲜菇工厂化栽培管理体系已较为成熟，人员进出频次受严格管控，作业流程标准化程度高，人为引入的热扰动可控且可建模。相较之下，榆黄蘑菇房虽在硬件环控设备层面达到了工厂化生产的基本要求，但配套的农艺操作规程尚不完善。例如，技术人员需频繁

进入培养区域观察子实体发育状态，导致门体多次开启，引发瞬态热冲击。此类非计划性、随机性强的人为扰动未被纳入控制模型的先验知识或实时输入，使得控制器无法及时做出补偿调节，进一步削弱了系统的鲁棒性。

综上所述，研究对比表明，PINNs－MPC 等先进控制策略的实际应用效果不仅取决于模型本身的算法性能，更受到作物生物学特性、环境动态复杂度以及农事管理制度规范化水平的综合制约。在环境扰动弱、运行模式稳定、管理成熟的海鲜菇菇房中，基于少量代表性控制基点的 PINNs－MPC 能够实现对全空间温度场的有效调控；而在温差大、通风频繁、人为干扰多且管理尚未规范化的榆黄蘑菇房中，仅依赖有限控制基点的闭环控制架构难以保障全局温控一致性。

3.2　物理信息神经网络 MPC 保守控制行为及其对节能潜力的制约

在温差较大的榆黄蘑菇房环境中，以 6 月 13 日为例进行统计分析。结果表明，采用基于物理信息神经网络的 MPC 策略时，空调累计制冷时长为 309 min，相较于传统阈值控制策略下的 346 min，节能率达到 10.7%。进一步地，将文献[31]基于内嵌热平衡方程约束 GRU－Attention 预测模型的 MPC 策略应用于同一菇房环境。该模型的训练集规模与 PINNs－MPC 保持一致，超参数设置参照文献[31]。结果显示，该策略的节能率提升至 13.1%，优于 PINNs－MPC，提升程度较为明显。

节能效果差异的主要原因在于，为确保菇房种植区温度始终不超过菌菇生长的上限阈值，PINNs－MPC 在预测与控制过程中对安全边界的要求更为保守，导致制冷干预频次增加，节能潜力受限。相比之下，基于内嵌热平衡方程约束 GRU－Attention 预测模型的 MPC 使用 16 个传感器读数的算术平均值作为系统代表温度，其本质上是一种空间低通滤波，能有效抑制个别传感器噪声或局部瞬态扰动，从而获得一个更稳定、更具整体热惯性代表性的状态反馈信号。

4　结论

（1）面向工厂化食用菌菇房中普遍存在的空间温度异质性问题，提出了一种基于 PINNs 的高精度温度场反演与节能预测控制方法。

（2）构建了多维度传感器优化选点模型，综合考虑平均温度均方根误差、方差贡献率、信息捕获率指标；经优化后，筛选出 6 组传感器数据，有效降低传感器部署成本以及信息冗余。

（3）构建了融合空气流动热传递的数据-物理融合温度场预测模型，实现了在有限传感器条件下对三维温度场时空演化的高保真反演，反演精度 RMSE 可达 0.267℃。

（4）PINNs－MPC 在海鲜菇菇房中实现全空间温控一致性，所有测点温度稳定维持在 14.2～15.2℃；而在榆黄蘑菇房中，受频繁通风扰动与非规范农事操作影响，回风口及出入口等局部观测点频繁超限，揭示了先进控制策略对环境动态特性与管理规范性的强依赖性。节能评估显示，PINNs－MPC 在榆黄蘑菇房中较传统阈值控制节能 10.7%，但其为保障温度安全边界而采取的保守控制行为限制了节能潜力；相比之下，基于热平衡方程约束的 GRU－Attention－MPC 策略节能率达 13.1%，优势明显。

（5）本文所提出的 PINN－MPC 协同框架有效融合了物理规律与稀疏观测数据，在提升温度场建模精度与空间感知能力方面取得实质性进展，为大型异质菇房的精准调控提供了新方法。同时，研究也揭示了模型性能受环境动态复杂度、扰动强度及农艺管理规范性的综合制约，为后续发展强鲁棒性、自适应性的智能调控系统指明了方向。

参　考　文　献

[1] 李长田，谭琦，边银丙，等. 中国食用菌工厂化的现状与展望[J]. 菌物研究，2019，17(1)：1－12.
LI Changtian, TAN Qi, BIAN Yinbing, et al. The status and prospection of edible mushroom industry in China[J]. Journal of Fungal Research, 2019, 17(1): 1－12. (in Chinese)

[2] 王丽娜. 食用菌工厂化生产经营绩效研究：与农户相对照[D]. 泰安：山东农业大学，2019.
WANG Li'na. Study on the performance of edible fungus factory production and management: comparison with farmers[D]. Taian: Shandong Agricultural University, 2019. (in Chinese)

[3] 谷继永. 食用菌工厂能源管理的思考[J]. 食药用菌，2023，31(1)：7－11.
GU Jiyong. Thoughts on energy management in mushroom factories[J]. Edible and Medicinal Mushrooms, 2023, 31(1): 7－11. (in Chinese)

[4] SETIAWAIT D A, UTOMO S G, PUTRA G M D, et al. Design of temperature and humidity control system on oyster mushroom plant house based on Internet of Things (IoT)[J]. IOP Conference Series: Earth and Environmental Science, 2021, 712(1): 012002.

[5] TAHERI S, HOSSEINI P, RAZBAN A. Model predictive control of heating, ventilation, and air conditioning (HVAC) systems: a state-of-the-art review[J]. Journal of Building Engineering, 2022, 60:105067.

[6] 田野,杨子轩,赵长春,等. 基于模型预测控制的新风机组节能优化控制方法[J]. 暖通空调,2023,53(增刊2):193-196.
TIAN Ye, YANG Zixuan, ZHAO Changchun, et al. A new energy-saving optimization control method for fresh air units based on model predictive control[J]. Heating Ventilating & Air Conditioning, 2023, 53(Supp.2): 193-196. (in Chinese)

[7] 李慧. 基于图卷积神经网络的数据中心冷却模型预测控制优化方法研究[J]. 制冷技术,2024,44(4):72-78.
LI Hui. Research on predictive control optimization method for data center cooling model based on graph convolutional neural network[J]. Chinese Journal of Refrigeration Technology, 2024, 44(4): 72-78. (in Chinese)

[8] 宫洵,任航,张华霖,等. 冬季网联纯电动汽车热泵空调生态制热控制方法[J]. 吉林大学学报(工学版),2025,55(3):820-828.
GONG Xun, REN Hang, ZHANG Hualin, et al. Eco-heating control method for connected electric automotive heat pump system in winter conditions[J]. Journal of Jilin University (Engineering and Technology Edition), 2025, 55(3): 820-828. (in Chinese)

[9] 王乘熙. 基于 MPC 算法的暖通空调系统舒适节能控制策略研究[D]. 苏州:苏州科技大学,2022.
WANG Chengxi. Research on comfort and energy saving control strategy of HVAC system based on MPC strategy[D]. Suzhou: Suzhou University of Science and Technology, 2022. (in Chinese)

[10] CUI B, DONG J, LEE S, et al. Model predictive control for active insulation in building envelopes[J]. Energy and Buildings, 2022, 267: 112108.

[11] WANG H, ZHAI Z. Advances in building simulation and computational techniques: a review between 1987 and 2014[J]. Energy and Buildings, 2016, 128:319-335.

[12] IGNJATOVI M G, BLAGOJEVI B D, STOJILJKOVI M M, et al. Energy performance of air-conditioned buildings based on short-term weather forecast[J]. Science and Technology for the Built Environment, 2022, 28:55-72.

[13] WANG X, XU Y, BAO Z, et al. Operation optimization of a solar hybrid CCHP system for adaptation to climate change[J]. Energy Conversion and Management, 2020, 220:113010.

[14] QIU S, LI Z, LI Z, et al. Model-free optimal chiller loading method based on Q-learning[J]. Science and Technology for the Built Environment, 2020, 26(8):1100-1116.

[15] FAN C, HINKELMAN K, FU Y, et al. Open-source Modelica models for the control performance simulation of chiller plants with water-side economizer[J]. Applied Energy, 2021, 299:117337.

[16] KWAK Y, SEO D, JANG C, et al. Feasibility study on a novel methodology for short-term real-time energy demand prediction using weather forecasting data[J]. Energy and Buildings, 2013, 57:250-260.

[17] 张馨,孔祥书,郑文刚,等. 基于模型预测控制的菇房空调节能控制方法[J]. 农业机械学报,2024,55(3):352-361.
ZAHNG Xin, KONG Xiangshu, ZHENG Wengang, et al. Energy-saving control method of air conditioning in mushroom housebased on model predictive control[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(3): 352-361. (in Chinese)

[18] 胡瑾,刘行行,孙大虎,等. 基于小样本迁移学习的跨地点菇房温度预测模型研究[J]. 农业机械学报,2026,57(2):375-383.
HU Jin, LIU Hangxing, SUN Dahu, et al. Cross-location mushroom house temperature prediction model based on small sample transfer learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2026,57(2):375-383. (in Chinese)

[19] 孙宗宇,李锦堂,乔镖,等. 典型热泵蓄能系统模型预测控制方法研究及模拟实验分析[J]. 建筑科学,2024,40(12):135-142,153.
SUN Zongyu, LI Jintang, QIAO Biao, et al. Case study and simulation of model predictive control method for typical heat pump thermal energy storage system[J]. Building Science, 2024, 40(12): 135-142,153. (in Chinese)

[20] 吴思明,陈伟利,邢晓柯,等. 基于 ARMA 模型的公共建筑空调系统优化技术研究[J]. 电器工业,2025(3):82-85.
WU Siming, CHEN Weili, XING Xiaoke, et al. Research on optimization technology of public building air conditioning system based on ARMA model[J]. China Electrical Equipment Industry, 2025(3): 82-85. (in Chinese)

[21] LIU X, WU X, SANG J, et al. Heat supply prediction method of a heat pump system based on timing analysis and a neural network[J]. Energy and Built Environment, 2025, 6(4):676-688.

[22] 海涛,曹先省,赵羿,等. ARIMA-BP 复合模型在建筑能耗预测中的应用研究[J]. 广西科技大学学报,2018,29(3):30-36.
HAI Tao, CAO Xianxing, ZHAO Yi, et al. The application of ARIMA-BP neural network composite model in building energy consumption forecast[J]. Journal of Guangxi University of Science and Technology, 2018, 29(3): 30-36. (in Chinese)

[23] SMERTINAS J, BACHER P, LINDSTRÖM E. Conditional parametric ARMAX models for observed hourly heat-load dynamics in apartment buildings[J]. Sustainable Cities and Society, 2025, 122: 106235.

[24] 胡瑾,雷文晔,卢有琦,等. 基于 1D CNN-GRU 的日光温室温度预测模型研究[J]. 农业机械学报,2023,54(8):339-346.

HU Jin, LEI Wenye, LU Youqi, et al. Solar greenhouse temperature prediction model based on 1D CNN - GRU[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(8):339 - 346. (in Chinese)

[25] YU Y, SI X, HU C, et al. A review of recurrent neural networks: LSTM cells and network architectures[J]. Neural Computation, 2019, 31(7):1235 - 1270.

[26] QIAN K, TIAN L, BAO J. Frequency-domain physical constrained neural network for nonlinear system dynamic prediction[J]. Engineering Applications of Artificial Intelligence, 2023, 122:106127.

[27] YE Y, FAULKNER C A, XU R, et al. System modeling for grid-interactive efficient building applications[J]. Journal of Building Engineering, 2023, 69:106148.

[28] 邹宇航,王明飞,张馨,等. 基于模型预测控制的工厂化菇房空调调控方法[J]. 中国农机化学报,2024,45(6):98 - 105.
ZOU Yuhang, WANG Mingfei, ZHANG Xin, et al. Control method of factory mushroom air conditioning based on model predictive control[J]. Journal of Chinese Agricultural Mechanization, 2024, 45(6): 98 - 105. (in Chinese)

[29] AHMAD T, CHEN H. Nonlinear autoregressive and random forest approaches to forecasting electricity load for utility energy management systems[J]. Sustainable Cities and Society, 2019, 45:460 - 473.

[30] TALIB A, PARK S, IM P, et al. Grey-box and ANN-based building models for multistep-ahead prediction of indoor temperature to implement model predictive control[J]. Engineering Applications of Artificial Intelligence, 2023, 126:107115.

[31] 孔祥书,郑文刚,张馨,等. 基于数据-物理混合模型的菇房空调节能控制方法[J]. 农业工程学报,2025,41(4):309 - 317.
KONG Xiangshu, ZHENG Wengang, ZHANG Xin, et al. Energy-saving control method of air conditioning in mushroom house based on data-physics mixed mode[J]. Transactions of the CSAE, 2025, 41(4): 309 - 317. (in Chinese)

[32] 徐立鸿,徐赫,蔚瑞华. 温室蓝莓光温协调优化模型与控制策略研究[J]. 农业机械学报,2022,53(1):360 - 369.
XU Lihong, XU He, WEI Ruihua. Optimal model of blueberry greenhouse light and temperature coordination[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022,53(1):360 - 369. (in Chinese)

[33] CHEN Y, YANG Q, CHEN Z, et al. Physics-informed neural networks for building thermal modeling and demand response control[J]. Building and Environment, 2023, 234:110149.

[34] TANG L, XIE H, WANG Y, et al. Deeply flexible commercial building HVAC system control: a physics-aware deep learning-embedded MPC approach[J]. Applied Energy, 2025, 388: 125631.

[35] LIANG X, LIU Y, CHEN S, et al. Physics-informed neural network for chiller plant optimal control with structure-type and trend-type prior knowledge[J]. Applied Energy, 2025, 390: 125857.

[36] 李浩,王晓原,韩俊彦,等. 基于高德导航数据与 FOA - GRNN 模型的驾驶倾向性辨识方法[J]. 交通信息与安全,2022,40(2):63 - 72.
LI Hao, WANG Xiaoyuan, HAN Junyan, et al. A method for identifying temperament propensity of drivers based on AUTONAVI navigation data and a FOA - GRNN model[J]. Journal of Transport Information and Safety, 2022, 40(2): 63 - 72. (in Chinese)

[37] AVCI M, ERKOC M, RAHMANI A, et al. Model predictive HVAC load control in buildings using real-time electricity pricing[J]. Energy and Buildings, 2013, 60:199 - 209.

(上接第 382 页)

[17] 白国星, 刘丽, 孟宇, 等. 基于非线性模型预测控制的移动机器人实时路径跟踪[J]. 农业机械学报, 2020, 51(9): 47 - 52, 60.
BAI Guoxing, LIU Li, MENG Yu, et al. Real-time path tracking of mobile robot based on nonlinear model predictive control[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(9): 47 - 52, 60. (in Chinese)

[18] ZHAO K G, WANG C X, XIAO G Q, et al. Research for nonlinear model predictive controls to laterally control unmanned vehicle trajectory tracking[J]. Applied Sciences, 2020, 10(17): 6034.

[19] 刘文龙, 郭锐, 赵静一. 基于反馈线性化的插秧机路径跟踪模糊预测函数控制[J]. 农业工程学报, 2024, 40(22): 51 - 61.
LIU Wenlong, GUO Rui, ZHAO Jingyi. Fuzzy predictive function control for the path tracking of transplanters using feedback linearization[J]. Transactions of the CSAE, 2024, 40(22): 51 - 61. (in Chinese)

[20] YU S Y, GUO Y, MENG L Y, et al. MPC for path following problems of wheeled mobile robots[J]. IFAC-Papers on Line, 2018, 51(20): 247 - 252.